

SENASTIKA Universitas Malikussaleh

PREDIKSI KONSUMSI ENERGI LISTRIK RUMAH TANGGA MENGGUNAKAN ALGORITMA GRADIENT BOOSTING

Marhaban Al-Maula^{*1}, Imay Syafitri², Teuku Muhammad Arinal³, Citra⁴, Munirul Ula⁵

(Teknik Informatika, Fakultas Teknik, Universitas Malikussaleh, Lhokseumawe)

Email: marhaban.210170053@mhs.unimal.ac.id, imay.210170072@mhs.unimal.ac.id,
citra.210170063@mhs.unimal.ac.id, teuku.210170085@mhs.unimal.ac.id, munirulula@unimal.ac.id

ABSTRAK

Penelitian ini bertujuan mengembangkan model prediksi konsumsi energi listrik rumah tangga menggunakan Algoritma Gradient Boosting, mengevaluasi akurasi, serta mengidentifikasi faktor-faktor yang mempengaruhi pola konsumsi energi. Model ini diharapkan berkontribusi pada efisiensi energi dan mendukung manajemen energi real-time di rumah pintar. Penelitian ini menggunakan pendekatan kuantitatif dengan Algoritma Gradient Boosting untuk memprediksi konsumsi energi listrik. Dataset diambil dari kaggle.com dan dievaluasi menggunakan MAE, MSE, RMSE, dan MAPE. Model ini dianalisis melalui visualisasi hasil prediksi terhadap data asli untuk mengidentifikasi kesalahan dan meningkatkan akurasi prediksi. Hasil penelitian menunjukkan bahwa model Gradient Boosting mampu memprediksi konsumsi energi listrik dengan akurasi tinggi. Nilai MAE, MSE, RMSE, dan MAPE yang rendah mengindikasikan kesalahan prediksi kecil. Namun, beberapa outlier masih muncul, menunjukkan potensi peningkatan akurasi model dengan mempertimbangkan variabel tambahan. Algoritma Gradient Boosting mampu memberikan prediksi konsumsi energi listrik rumah tangga dengan akurasi tinggi, ditunjukkan oleh nilai MAE, MSE, RMSE, dan MAPE yang rendah. Meskipun demikian, terdapat beberapa outlier yang mengindikasikan potensi peningkatan akurasi prediksi melalui penambahan variabel lain. Implementasi model ini diharapkan dapat mendukung penghematan energi dan pengurangan emisi karbon, terutama dalam integrasi dengan solusi rumah pintar.

Keywords: *Akurasi prediksi, Algoritma Gradient Boosting, Efisiensi energi, Metrik Evaluasi, Prediksi konsumsi energi Listrik*

1. PENDAHULUAN

Penelitian ini berfokus pada penggunaan algoritma Gradient Boosting untuk memperkirakan konsumsi energi listrik suatu rumah menggunakan data digital. Sejalan dengan meningkatnya penggunaan sensor pintar dan sistem manajemen energi di rumah-rumah yang terhubung, terdapat sejumlah besar data yang tersedia mengenai penggunaan energi. Jumlah energi yang dikonsumsi di rumah tradisional terus meningkat seiring dengan bertambahnya jumlah penduduk dan penggunaan perangkat elektronik dalam kehidupan sehari-hari. Dalam upaya global yang sedang berlangsung untuk mengurangi emisi karbon dan meningkatkan efisiensi energi, prediksi akurat mengenai penggunaan listrik menjadi semakin penting. Teknologi digital seperti smart meter dan Internet of Things telah membuat data konsumsi energi tersedia secara real time dan dalam jumlah besar. Namun tantangan yang muncul adalah bagaimana memanfaatkan data-data tersebut di atas untuk menentukan penggunaan energi secara efisien dan efektif.

Tujuan utama dari penelitian Implementasi Algoritma Gradient Boosting untuk Prediksi Konsumsi Energi Listrik Rumah Tangga Menggunakan Data Digital adalah untuk mengembangkan model prediktif yang akurat dalam membayangkan konsumsi energi listrik rumah tangga. Penelitian ini bertujuan memanfaatkan algoritma Gradient Boosting untuk mengolah data digital yang dihasilkan oleh perangkat pintar atau smart meter, sehingga mampu memberikan prediksi yang lebih tepat terkait penggunaan energi. Selain itu, penelitian ini juga bertujuan mengidentifikasi faktor-faktor utama yang mempengaruhi konsumsi energi listrik, sehingga dapat memberikan wawasan lebih lanjut tentang pola perilaku konsumsi energi di rumah tangga. Dengan prediksi yang lebih akurat, penelitian ini diharapkan dapat mendukung pemeliharaan energi rumah tangga yang lebih efisien, baik dalam hal penggunaan energi maupun penghematan biaya. Selanjutnya, model implementasi ini diharapkan menghasilkan sistem prediksi berbasis data digital yang dapat digunakan secara real-time, yang nantinya dapat diintegrasikan dengan solusi rumah pintar (smart home). Hasil akhir dari penelitian ini diharapkan mampu memberikan kontribusi dalam mendukung efisiensi energi dan pengurangan emisi karbon di sektor rumah tangga, serta mendorong pengembangan solusi berkelanjutan dalam manajemen energi.

Kajian ini penting karena konsumsi energi terbaru merupakan salah satu faktor utama yang mempengaruhi perkembangan perekonomian dan lingkungan setempat. Seiring dengan meningkatnya jumlah penduduk dan

urbanisasi, kebutuhan energi listrik pun terus meningkat, sehingga penting untuk mengalokasikan konsumsi energi secara lebih efisien. Saat ini, teknologi digital seperti smart meter dan pintar memungkinkan pengumpulan data konsumsi energi yang lebih tepat dan real-time. Namun, untuk memanfaatkan data ini sebaik-baiknya, diperlukan model prediktif yang dapat mengukur dan menganalisis pola konsumsi energi secara akurat. Hal ini menyoroti pentingnya algoritma Gradient Boosting, yang dikenal efisiensinya dalam menganalisis data yang kompleks dan dapat memberikan solusi untuk meningkatkan efisiensi energi bangunan.

Kontribusi penelitian ini pada bidang prediksi konsumsi energi didasarkan pada kemampuan algoritma Gradient Boosting dalam memproses data digital dengan lebih efektif.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan berbasis algoritma manual dengan beberapa tahapan sistematis mulai dari pengolahan data hingga evaluasi model prediksi. Tahapan penelitian yang dilakukan dijelaskan sebagai berikut:

2.1 Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan Algoritma Gradient Boosting untuk memprediksi harga berdasarkan dataset yang diambil dari *kaggle.com*. Algoritma ini dipilih karena kemampuannya untuk menghasilkan prediksi yang akurat dengan menggabungkan beberapa model keputusan. Fokus penelitian ini adalah mengukur performa model dengan menggunakan metrik evaluasi seperti MAE, MSE, RMSE, dan MAPE.

2.2 Dataset

Dataset yang digunakan dalam penelitian ini berasal dari *kaggle.com* yang berisi informasi harga yang digunakan sebagai variabel target. Data dibagi menjadi data latih (training data) dan data uji (test data) untuk memastikan model dapat diuji dengan baik terhadap data yang tidak pernah dilihat sebelumnya. Dataset tersebut mencakup sejumlah besar data, namun hanya lima data teratas yang ditampilkan dalam hasil dan pembahasan untuk representasi visual. Berikut tampilan dataset yang digunakan dalam penelitian ini. <https://www.kaggle.com/datasets/jaganadhg/house-hold-energy-data>

1	TYPE	DATE	START TIME	END TIME	USAGE	UNITS	COST	NOTES
2	Electric usage	22/10/2016	00.00	00.14	0,01 kWh		\$0,00	
3	Electric usage	22/10/2016	00.15	00.29	0,01 kWh		\$0,00	
4	Electric usage	22/10/2016	00.30	00.44	0,01 kWh		\$0,00	
5	Electric usage	22/10/2016	00.45	00.59	0,01 kWh		\$0,00	
6	Electric usage	22/10/2016	01.00	01.14	0,01 kWh		\$0,00	
7	Electric usage	22/10/2016	01.15	01.29	0,01 kWh		\$0,00	
8	Electric usage	22/10/2016	01.30	01.44	0,01 kWh		\$0,00	
9	Electric usage	22/10/2016	01.45	01.59	0,01 kWh		\$0,00	
10	Electric usage	22/10/2016	02.00	02.14	0,02 kWh		\$0,00	
11	Electric usage	22/10/2016	02.15	02.29	0,02 kWh		\$0,00	

Gambar 1. dataset yang digunakan

2.3 Algoritma yang Digunakan

Algoritma Gradient Boosting digunakan untuk melakukan prediksi harga. Algoritma ini bekerja dengan menggabungkan beberapa model keputusan secara iteratif untuk meminimalkan kesalahan prediksi pada setiap iterasi. Hal ini dilakukan dengan cara mengurangi residu dari model sebelumnya untuk meningkatkan akurasi model secara keseluruhan.

2.4 Evaluasi Model:

Kinerja model dievaluasi menggunakan empat metrik utama:

MAE (Mean Absolute Error) Mengukur rata-rata kesalahan absolut antara prediksi dan nilai sebenarnya. Nilai MAE yang rendah mengindikasikan bahwa model melakukan prediksi dengan akurasi yang baik.

MSE (Mean Squared Error) Mengukur rata-rata kesalahan kuadrat antara prediksi dan nilai sebenarnya. MSE memberikan penalti lebih besar pada kesalahan yang lebih besar, sehingga membantu mendeteksi outlier.

RMSE (Root Mean Squared Error) Merupakan akar dari MSE yang memberikan ukuran kesalahan prediksi dalam satuan yang sama dengan data asli. Nilai RMSE yang kecil menunjukkan prediksi yang akurat.

MAPE (Mean Absolute Percentage Error) Mengukur kesalahan prediksi dalam bentuk persentase, yang memberikan gambaran seberapa besar kesalahan relatif dari nilai yang diprediksi.

2.5 Visualisasi Hasil

Untuk membantu pemahaman hasil prediksi, grafik perbandingan antara harga asli dan harga yang diprediksi oleh model disajikan. Grafik ini menunjukkan hubungan antara kedua variabel tersebut dan memudahkan dalam mengidentifikasi outlier atau kesalahan prediksi yang signifikan.

2.6 Analisis dan Interpretasi

Hasil dari evaluasi model menunjukkan bahwa nilai MAE, MSE, RMSE, dan MAPE yang rendah menandakan bahwa model memiliki akurasi yang tinggi. Namun, masih terdapat beberapa outlier yang diidentifikasi melalui visualisasi, yang menunjukkan adanya kesalahan prediksi pada beberapa titik data.

2.7 Output

Hasil akhir dari penelitian ini adalah evaluasi model dengan penekanan pada Nilai MAE yang rendah menunjukkan akurasi prediksi yang tinggi.

Nilai MSE yang rendah menunjukkan bahwa kesalahan prediksi tersebar kecil.

Nilai R^2 yang mendekati 1 menunjukkan bahwa model sangat baik dalam menjelaskan variabilitas biaya penggunaan energi.

Hasil ini diharapkan dapat menjadi landasan untuk pengembangan lebih lanjut dalam prediksi biaya energi berbasis data.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Uji

	Actual Cost	Predicted Cost
0	0.01	0.010145
1	0.01	0.010145
2	0.01	0.010145
3	0.01	0.010145
4	0.01	0.010145

Gambar 2. Perbandingan Harga Data asli dan Harga hasil prediksi

Gambar I di atas menggambarkan perbandingan hasil prediksi yang dilakukan menggunakan Algoritma Gradient Boosting dengan dataset yang diambil dari kaggle.com. Pada gambar tersebut, hanya ditampilkan lima data teratas dari keseluruhan dataset yang tersedia, mengingat jumlah data yang cukup besar sehingga tidak memungkinkan untuk menampilkan semuanya dalam satu gambar. Dari perbandingan yang terlihat, hasil prediksi yang dihasilkan oleh algoritma ini menunjukkan kedekatan dengan data asli. Meskipun terdapat sedikit perbedaan antara harga asli dan harga hasil prediksi, perbedaan ini tidak signifikan. Hal ini menunjukkan bahwa Algoritma Gradient Boosting mampu memberikan hasil yang akurat dalam melakukan prediksi harga. Keakuratan prediksi ini sebagian besar disebabkan oleh pola harga pada data asli, di mana pada urutan pertama hingga ke-17, harga yang tercatat adalah konstan. Kondisi ini berdampak pada hasil prediksi yang juga cenderung konstan pada urutan data yang sama. Setelah urutan ke-17, harga mulai mengalami perubahan yang lebih dinamis karena adanya fluktuasi dalam data asli. Perubahan ini pun tercermin dalam hasil prediksi, di mana algoritma mulai menyesuaikan modelnya terhadap perbedaan harga yang lebih kompleks. Meskipun demikian, penting untuk dicatat bahwa Algoritma Gradient Boosting memanfaatkan beberapa teknik pemodelan untuk meminimalkan kesalahan prediksi, seperti menggunakan pendekatan ansambel untuk menggabungkan beberapa model keputusan. Hasil yang diperoleh menunjukkan bahwa pendekatan ini cukup efektif dalam mengatasi variasi harga yang ada pada dataset, sehingga membuat prediksi mendekati nilai sebenarnya.

Mean Absolute Error (MAE): 0.0015759036122986291
Mean Squared Error (MSE): 2.004910004802979e-05
Root Mean Squared Error (RMSE): 0.0044776221421676254
Mean Absolute Percentage Error (MAPE): 5.130892868106731

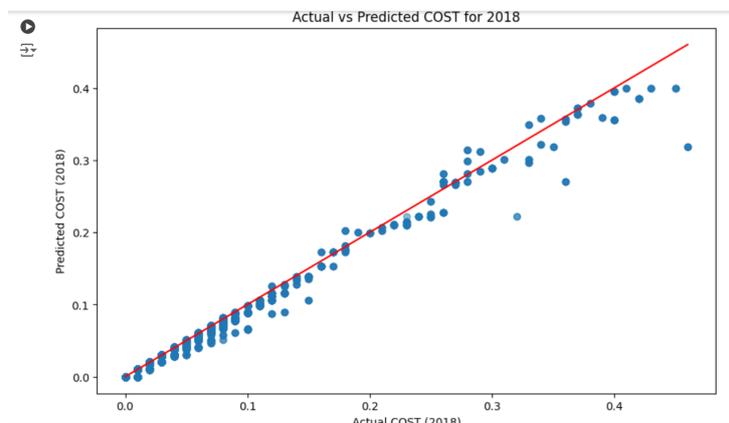
Gambar 3. Output matrix MAE, MSE, RMSE dan MAPE

Nilai MAE (Mean Absolute Error) yang dihasilkan sebesar 0.0015759036122986291 mencerminkan bahwa rata-rata kesalahan prediksi yang dibuat oleh model sangat kecil. Dengan nilai MAE yang rendah, dapat disimpulkan bahwa perbedaan antara harga prediksi dan harga asli tidak signifikan, yang merupakan indikasi bahwa model mampu memprediksi dengan cukup tepat. Nilai ini penting karena memberikan gambaran yang mudah dipahami tentang performa model dalam menangani variasi data yang ada.

Selain itu, nilai MSE (Mean Squared Error) sebesar 2.004910004802979e-05 menunjukkan bahwa kesalahan kuadrat rata-rata juga sangat rendah. Nilai ini menjadi penting karena MSE memberikan penekanan lebih besar pada kesalahan yang lebih besar. Fakta bahwa nilai MSE sangat kecil mengindikasikan bahwa prediksi yang jauh dari nilai asli sangat jarang terjadi. Ini berarti model cukup stabil dan konsisten dalam memberikan hasil yang mendekati nilai asli, tanpa menghasilkan outlier yang signifikan.

Selanjutnya, nilai RMSE (Root Mean Squared Error) sebesar 0.0044776221421676254, yang merupakan akar dari MSE, juga menegaskan bahwa kesalahan prediksi berada dalam rentang yang sangat kecil, yaitu sekitar 0.0045 unit dari harga sebenarnya. Nilai ini memberikan indikasi bahwa prediksi yang dilakukan oleh model sangat akurat dalam skala kecil.

Selain itu, nilai MAPE (Mean Absolute Percentage Error) sebesar 5.130892868106731% menunjukkan bahwa kesalahan prediksi model berkisar sekitar 5.13% dari nilai aslinya. Dalam konteks akurasi prediksi, MAPE yang lebih rendah dari 10% umumnya dianggap sebagai indikasi bahwa model bekerja dengan akurat. Dengan demikian, nilai 5.13% menunjukkan bahwa model ini cukup akurat, meskipun masih ada ruang untuk perbaikan, khususnya dalam meningkatkan akurasi pada beberapa kasus spesifik. Kinerja model ini dapat dianggap cukup memadai dan sesuai dengan standar umum dalam pemodelan prediktif, terutama dalam skenario di mana kesalahan kecil dapat ditoleransi.



Gambar 4 Grafik perbandingan antara Harga sebenarnya (actual COST) dan harga yang diprediksi oleh model (predicted COST)

Sumbu X (horizontal) menunjukkan nilai actual cost (harga aktual). Sumbu Y (vertikal) menunjukkan nilai predicted cost (harga yang diprediksi). Titik-titik biru mewakili pasangan nilai (COST aktual, COST prediksi) untuk setiap observasi dalam dataset. Semakin dekat titik-titik ini ke garis merah, semakin akurat prediksi model. Kemiringan garis menunjukkan bahwa ada hubungan positif antara biaya aktual dan biaya yang diprediksi. Ini berarti bahwa ketika biaya aktual meningkat, biaya yang diprediksi juga cenderung meningkat. Dari grafik, terlihat bahwa sebagian besar titik berada dekat dengan garis merah, menunjukkan bahwa model prediksi cukup akurat. Namun, ada beberapa titik yang terletak jauh dari garis merah, menunjukkan adanya outlier atau kesalahan prediksi yang signifikan pada biaya tertentu. Secara keseluruhan, grafik ini menunjukkan bahwa model yang digunakan untuk memprediksi biaya konsumsi listrik cukup efektif, tetapi masih ada beberapa nilai yang tidak diprediksi dengan baik. Untuk meningkatkan akurasi, perlu dilakukan analisis lebih lanjut terhadap titik-titik yang berada jauh dari garis prediksi dan mungkin mempertimbangkan variabel lain yang bisa mempengaruhi biaya.

2018 Mean Absolute Error (MAE): 0.0019819425270840687
 2018 Mean Squared Error (MSE): 2.2940556901244602e-05
 2018 Root Mean Squared Error (RMSE): 0.004789630142426929
 2018 Mean Absolute Percentage Error (MAPE): 8.191569564349004

Gambar 5 MAE,MSE,RMSE dan MAPE data aktual dan prediksi tahun 2018

Nilai MAE yang dihasilkan adalah 0.0019819425270840687. Ini adalah rata-rata dari nilai absolut kesalahan antara nilai prediksi dan nilai sebenarnya. Nilai yang relatif rendah ini menunjukkan bahwa model, secara rata-rata, membuat prediksi yang dekat dengan nilai sebenarnya. Nilai MSE yang dihasilkan adalah 2.004910004802979e-05. Nilai yang sangat rendah ini menunjukkan bahwa kesalahan besar sangat jarang terjadi, sehingga model memiliki konsistensi yang baik dalam melakukan prediksi dengan kesalahan yang relatif rendah.. Hal ini juga mengindikasikan bahwa model memiliki kinerja yang baik. Nilai RMSE yang dihasilkan adalah 0.004789630142426929. Sama seperti MSE, nilai RMSE yang kecil ini menunjukkan bahwa model melakukan prediksi dengan kesalahan yang sangat kecil. Nilai MAPE yang dihasilkan adalah 8.191569564349004. MAPE yang lebih rendah dari 10% dianggap akurat, sedangkan MAPE lebih tinggi menunjukkan tingkat ketidakakuratan yang lebih besar. Oleh karena itu, nilai 8.19% bisa diinterpretasikan sebagai indikasi bahwa model tersebut cukup akurat, meskipun ada ruang untuk peningkatan. Sebuah nilai RMSE yang rendah mengindikasikan bahwa model memberikan prediksi yang secara umum tepat dan konsisten, dengan tingkat kesalahan yang kecil secara keseluruhan.

3.2 Diskusi

Pada Gambar 2, terlihat bahwa model mampu menghasilkan prediksi yang sangat mendekati harga asli, terutama pada data awal di mana harga konstan. Hal ini menunjukkan bahwa model dapat menangkap pola data yang stabil dengan baik. Namun, ketika harga mulai bervariasi, prediksi model juga tetap mengikuti pola tersebut, meskipun dengan beberapa penyimpangan kecil. Perubahan harga asli yang terjadi setelah urutan ke-17 menunjukkan model tetap beradaptasi dengan data yang lebih dinamis. Model prediktif yang diuji menggunakan Algoritma Gradient Boosting menunjukkan performa yang baik dengan kesalahan prediksi yang kecil berdasarkan metrik MAE, MSE, RMSE, dan MAPE. Meskipun demikian, beberapa penyimpangan atau outlier masih terjadi pada beberapa titik data, yang menunjukkan potensi untuk peningkatan lebih lanjut, seperti mempertimbangkan variabel tambahan atau memperbaiki outlier agar prediksi semakin akurat. Penelitian menemukan adanya beberapa outlier dalam hasil prediksi yang menunjukkan kesalahan. Hal ini disebabkan oleh kompleksitas pola konsumsi energi yang tidak sepenuhnya ditangkap oleh model, terutama saat fluktuasi besar terjadi. Meskipun jumlah outlier sedikit, tetap memengaruhi akurasi keseluruhan. Identifikasi dan analisis lebih lanjut terhadap outlier dapat meningkatkan akurasi, misalnya dengan menambahkan variabel relevan seperti cuaca atau kebiasaan penggunaan energi. Penelitian ini berkontribusi pada manajemen energi rumah pintar dengan model prediksi real-time yang membantu efisiensi energi dan pengurangan emisi karbon, serta memberikan rekomendasi penghematan berdasarkan prediksi konsumsi. Penelitian ini dapat dikembangkan dengan algoritma lain dan dataset lebih besar, serta penambahan variabel seperti cuaca dan aktivitas penghuni untuk meningkatkan akurasi prediksi.

4. Kesimpulan

Berdasarkan hasil pengujian terhadap kinerja algoritma Gradient Boosting dalam memprediksi konsumsi energi listrik rumah tangga, bisa disimpulkan bahwa proses evaluasi kinerja model dilakukan dalam beberapa tahapan. Pertama, dilakukan analisis data untuk memahami pola dan tantangan yang ada dalam konsumsi energi. Data yang digunakan diambil dari kaggle.com, dan diproses melalui pembersihan serta penyeimbangan data. Setelah itu, data dibagi menjadi dua bagian, yaitu 70% untuk pelatihan dan 30% untuk pengujian, dengan tujuan mengevaluasi performa algoritma secara lebih obyektif. Model ini kemudian dievaluasi menggunakan beberapa metrik utama seperti MAE (Mean Absolute Error), MSE (Mean Squared Error), RMSE (Root Mean Squared Error), dan MAPE (Mean Absolute Percentage Error) untuk mengukur tingkat akurasi prediksi. Hasilnya, algoritma Gradient Boosting berhasil memberikan prediksi yang cukup akurat dengan nilai MAE, MSE, RMSE, dan MAPE yang tergolong rendah. Namun, masih ditemukan beberapa outlier, yang menunjukkan bahwa masih ada peluang untuk meningkatkan akurasi model, mungkin dengan menambahkan variabel lain atau melakukan optimasi lebih lanjut. Kemampuan model untuk menangkap pola konsumsi energi yang stabil memperlihatkan bahwa prediksi yang dihasilkan sudah baik, meskipun masih ada sedikit penyimpangan pada data yang lebih dinamis. Secara keseluruhan, algoritma Gradient Boosting sudah terbukti cukup efektif dalam memprediksi konsumsi energi listrik, dan penerapannya dalam manajemen energi rumah pintar bisa membantu meningkatkan efisiensi energi serta mengurangi emisi karbon. Jadi, model ini memiliki potensi besar untuk digunakan sebagai solusi dalam

mendukung efisiensi energi di rumah tangga dan bisa menjadi dasar pengembangan lebih lanjut dalam prediksi konsumsi energi berbasis data real-time.

5. DAFTAR PUSTAKA

- [1] Dahlia, R., & Agustyaningrum, C. I. (2022). Perbandingan Gradient Boosting dan Light Gradient Boosting Dalam Melakukan Klasifikasi Rumah Sewa. *Jurnal Nasional Komputasi Dan Teknologi Informasi (JNKTI)*, 5(6), 1016–1020. <https://doi.org/10.32672/jnkti.v5i6.5460>
- [2] Firmansyah, H., & Abidin, Z. (2022). Penerapan Algoritma Gradient Boosted Decision Trees Pada Adaboost Untuk Klasifikasi Status Desa. *Jurnal Informatika UPS*, 1(1), 27–35. Retrieved from <https://jiaii.upstegal.ac.id/index.php/jiaii/article/view/14>.
- [3] Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- [4] Kim, S., & Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3), 669–679. <https://doi.org/10.1016/j.ijforecast.2015.12.003>
- [5] Komansilan, R., Tarigan, V., & Yusupa, A. (2024). Analisis Perbandingan Metode Trend Moment dan Regresi Linear Untuk Meramal Harga Saham Bank BRI. *J-SISKO TECH (Jurnal Teknologi Sistem Informasi Dan Sistem Komputer TGD)*, 7(1), 24. <https://doi.org/10.53513/jsk.v7i1.9474>
- [6] Nie, P., Roccotelli, M., Fanti, M. P., Ming, Z., & Li, Z. (2021). Prediction of home energy consumption based on gradient boosting regression tree. *Energy Reports*, 7, 1246–1255. <https://doi.org/10.1016/j.egyr.2021.02.006>
- [7] Nur Fauziyah, E., & Rohman Nudin, S. (2021). Sistem Pendukung Keputusan Penentuan Jurusan di SMKN 1 Pungging Menggunakan Gradient Boosting Tree. *Jurnal Ilmiah Teknologi Informasi Dan Robotika*, 3(1), 42–50. <https://doi.org/10.33005/jifti.v3i1.49>
- [8] Nyoman, I., Wardana, K., Jawas, N., Komang, I., & Aryanto, A. A. (2020). Prediksi Penggunaan Energi Listrik pada Rumah Hunian Menggunakan Long Short-Term Memory. *TIERS Information Technology Journal*, 1(1), 1–11. Retrieved from <http://journal.undiknas.ac.id/index.php/tiers>
- [9] Priyono, H., Sari, R., & Mardiana, T. (2022). Klasifikasi Pemilihan Jurusan Sekolah Menengah Kejuruan Menggunakan Gradient Boosting Classifier. *Jurnal Informatika*, 9(2), 131–139. <https://doi.org/10.31294/inf.v9i2.12654>
- [10] Upadhyay, D., Manero, J., Zaman, M., & Sampalli, S. (2021). Learning Classifiers for Intrusion Detection on Power Grids. *Ieee Transactions on Network and Service Management*, 18(1), 1104–1116.